

## 自己位置推定用環境情報重要度テーブルの生成法

Generation Method of Information Significance Table on Environment for Self-position  
Estimation of Autonomous Mobile robot道木 加絵<sup>†</sup>, 河原 達哉<sup>††</sup>, 鳥井 昭宏<sup>††</sup>, 植田 明照<sup>††</sup>

Kae Doki, Tatsuya Kawara, Akihiro Torii, Akiteru Ueda

**Abstract** We propose a new generation method of the information significance table on the environment around the robot for changing the calculation cost of self-position estimation. In this method, the calculation cost is varied by changing the number of the image pieces for self-position estimation. Therefore, the information significance table is generated in the process of Genetic Algorithm for selecting image pieces.

## 1. はじめに

近年、様々な分野でロボットの開発・研究が行われている。従来のロボットは定められた単純な作業を繰り返すだけの産業用のロボットであったが[1]、技術の発展に伴ってロボットの活動の場が広がり、様々な状況に対応できるロボットが必要となった。しかし従来の産業用ロボットのように、ロボットが直面し得るすべての状況に対応した行動をあらかじめ決定しておくことは極めて困難である。そこで近年、ロボット自身が直面した状況に応じた行動を自身で判断し決定する自律性を持たせた自律移動ロボットの研究が盛んに行われるようになった。自律移動ロボットとは、作業空間を移動しながら現在の状況に適した行動を、自分自身で決定し行動する移動ロボットである。そのためにはセンサ等を用いて周囲の状況を認識し、その情報を元に状況に応じた適切な行動を決定しなければならない。自律移動ロボットの行動決定方法は従来の研究により様々な方法が提案されているが、ロボットが直面する可能性のある全ての状況に適した行動を設計者が事前に設定する方法が一般的である。しかし最適な行動を事前に設定しておく事は困難である。そこで遭遇する状況に適切な行動を実時間で獲得する手法が考えられた[2]。これはロボットがリアルタイムで現在の状況に適した行動を探索し行動する実時間探索により行動を獲得する方法であり、これにより時間と共に変化する様々な状況に適した行動をすることが可

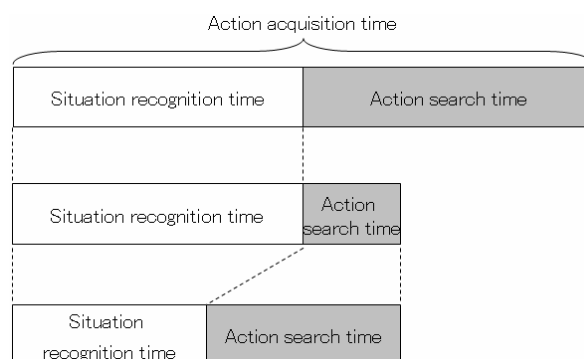
<sup>†</sup> 愛知工業大学 工学部 機械学科 (豊田市)<sup>††</sup> 愛知工業大学 工学部 電気学科 (豊田市)<sup>†††</sup> 愛知工業大学 大学院電気電子工学専攻 (豊田市)

Fig.1 Relationship between time for action acquisition and time for situation recognition

能である。そこで本研究では、実時間探索による自律移動ロボットの行動獲得手法に着目する。

自律移動ロボットが実時間探索により行動を獲得する場合、行動獲得には現在の状況を認識するための「状況認識」と、状況に適した行動を探索する「行動探索」の2つが必要である。したがって行動獲得時間は状況認識を行うための状況認識時間、行動探索を行うための行動探索時間の2つに分けられる。また行動獲得に用いる事のできる時間は限られており、その長さは周囲の状況により変化する。Fig.1 の上に示すように、ある行動獲得時間に最適な状況認識と行動探索を行う時間を設定した場合、Fig.1 の中央に示すように状況の変化により行動獲得時間が短くなった場合行動探索を行う時間が短くなってしまい、必要最低限の行動探索も行えなくなってしまう。そこで Fig.1 の下に示すように、状況認識時間を減らし、行動探索時間とのバランスを取る事が必要とな

る。つまり行動獲得時間に応じた状況認識が必要となる。

本研究では状況認識方法の具体例として画像を用いた自己位置推定を考え、行動獲得時間に応じた自己位置推定を行うためのシステムの構築を行ってきた。そのシステムでは自己位置推定時間の変更を、画像サイズの変更により行っており、自己位置推定時間を短くする場合、画像サイズの縮小を行っている。しかし画像サイズの縮小は単純に自己位置推定に用いる情報を減少させているため、重要な情報が失われ、自己位置推定結果に悪影響を及ぼす可能性が考えられる。そこで自己位置推定時間を短くしても自己位置推定の精度をできるだけ落さないために、自己位置推定に用いる情報に重要度を設定し、より重要な情報から順に自己位置推定に用いることが必要となる。

そこで本研究ではそのために必要な、自己位置推定に用いる情報の重要度を示した環境情報重要度テーブルの生成方法を提案し、実機による走行実験によりその有効性を検証することを目的とする。本論文の構成について述べる。第 2 章において、提案する自律移動ロボットの自己位置推定システムについて述べる。第 3 章において、マッチング時間を可変にするための遺伝的アルゴリズムを用いた環境情報重要度テーブルの生成法について述べる。第 4 章において、本論文で提案した自己位置推定方法の有効性を示すため、実画像を用いた実験を行い、実験結果を示し考察について述べる。第 5 章において、本論文の結論を述べる。

## 2. 自己位置推定システム

### 2・1 問題設定

Fig.2 に作業環境の例と実際に使用するロボットを示す。本研究では作業環境として廊下等の屋内環境を想定し、自律移動ロボットがカメラから撮影された画像を用いて、各部屋の前などの事前に設定した位置をキーポイントとして認識する。

### 2・2 自己位置推定方法

本システムでは以下の順により自己位置推定を行う。

1. ロボットに搭載されたカメラにより画像を撮影し、この画像を入力画像とする。
2. 入力画像と、事前に撮影しておいた環境中の各位置を表す画像(以下、蓄積画像)を用いて画像マッチングを行い、最も入力画像と類似している画像を決定する。
3. 入力画像と最も類似している蓄積画像が表す環境中の位置を現在の位置と推定する。




Fig.2 Problem setup

類似度の指標には、照明変動に頑健な正規化相関係数を用いる。以下に正規化相関係数の式を示す。

$$R = \frac{\sum_x \sum_y^M \{f(x, y) - \bar{f}\} \cdot \{g(x, y) - \bar{g}\}}{\sqrt{\sum_x \sum_y^M \{f(x, y) - \bar{f}\}^2} \sqrt{\sum_x \sum_y^M \{g(x, y) - \bar{g}\}^2}} \quad (1)$$

ここで  $f(x, y)$ 、 $g(x, y)$  はそれぞれ入力画像と蓄積画像の値度値を表し、 $M \times N$  は画像サイズを表す。正規化相関係数は 2 枚の画像の共分散を正規化しているため値は -1~1 と取る。正規化相関係数が 1 近いほど 2 枚の画像は輝度値の傾向が似ており、画像の類似度が高く、-1 に近いほど 2 枚の画像は輝度値の傾向が似ておらず、画像の類似度が低い。よって入力画像と各蓄積画像とをマッチングし、最も高い正規化相関係数を取った蓄積画像が撮影された位置を、現在の位置として推定する。

## 3. 環境情報重要度テーブルの生成法


### 3・1 はじめに

自律移動ロボットが実時間探索で行動獲得を行う場合、行動獲得時間は限られており、その長さは状況により変化する。したがって行動獲得時間に応じた自己位置推定が必要とされるが、一般的に自己位置推定時間を短くすると、自己位置推定の精度は低下し、その結果得られる行動の精度も低下する。そこでロボットが獲得できる情報に重要度をつけ、より重要な情報から順に自己位置推定に用いる事で自己位置推定の精度の低下を防ぐ。本研究では状況に応じた自己位置推定を正規化相関係数の計算量を変化させることで行う。正規化相関係数の計算は画素単位の比較となり、その計算量は画像サイズ

$M \times N$  に大きく依存している。そこで画像マッチングに必要な計算時間を減らすために、斎藤ら[3]が提案しているように、正規化相関係数計算時に蓄積画像内画素の間引きを行うことにより、画像マッチングの高速化をはかる。本研究では、従来手法のように等間隔で機械的に間引くのではなく、マッチングの信頼性を維持しつつ、かつ効率的なマッチングが行えるように各蓄積画像に応じて画素の間引き方を変化させることが重要となる。つまり、各位置で取得した蓄積画像中の画素のうち、その位置の特徴を多く含む自己位置推定に有効な画素のみをマッチングに用いる。画素選択方法として画素単位での選択方法と、矩形領域の単位で選択・非選択を扱う矩形領域の単位での画素選択の2つが考えられる。このとき、画像の各画素は1画素単位では画像の特徴を表さず、複数の画素が集まることではじめて画像の特徴を表すと考えられる。また、任意の座標から領域を選択する場合、その領域の位置や領域の組み合わせは無数に存在するため、情報の重要度をつけることが困難になると考えられる。そこで、画像マッチングの際に画像を分割し、それらの分割画像(以下、領域)の中からいくつかの領域を選択し、選択された領域のみを使用して正規化相関係数の計算を行う。また、本研究では状況に応じた自己位置推定を、正規化相関係数の計算量を変化させることで行う。正規化相関係数の計算に用いる領域数を状況に応じて変化させる事により正規化相関係数の計算時間を変化させ、状況に応じた自己位置推定を行う。行動獲得時間が長いときは多くの領域を選択することで詳細な自己位置推定を行い、行動獲得時間が短い場合には少ない領域を選択することで短い時間での自己位置推定を行う。またこのときに選択される領域の組み合わせは、その位置を認識するのに重要な情報を多く持った領域であることが望ましいと考えられる。そこで本研究では各領域の重要度を示す環境情報重要度テーブルを生成し、そのテーブルを元に重要な領域から順に選択し、正規化相関係数の計算に用いる。

### 3・2 遺伝的アルゴリズムによる領域選択

自律移動ロボットが実時間探索による行動獲得を行う場合、行動獲得に用いる事のできる時間は限られている。したがって、自己位置推定に用いる事のできる時間は限られているため、効率の良い計算を行うために自己位置推定に有効な領域のみを計算に用いる必要がある。本研究では分割した領域の組み合わせの中から、その位置を認識するのに重要な情報を多く持った領域の組み合わせを見つける方法の1つとして大域的な解探索に優れている遺伝的アルゴリズム[4](Genetic Algorithm:GA)を用い、その過程で得られた情報を元に環境情報重要度



(a)Structure of chromosome (b) Squares selected by Chromosome

Fig.3 Relationship between chromosome and selected squares

テーブルの生成を行う。GAとは生物が交叉、突然変異、淘汰を繰り返しながら、環境に適合するように進化していく過程を工学的に模倣したものであり、環境に適合する度合いを数値で表せば、進化して生き残った個体の数値は徐々に高くなっていくことになる。そこでコンピュータ上に仮想生命を生成し、その環境に対する適応度を最適化問題の目的関数に一致させ、進化の過程をシミュレーションすることによって最適化問題を解くものである。以下にその方法を述べる。

あらかじめ撮影しておいた環境中の各位置を示す蓄積画像を、縦横それぞれ  $x$  等分し、その中からその位置を認識するのに重要な情報を多く持った領域の組み合わせを見つける。GAに用いる染色体をFig.3の(a)に、その染色体によって選択される領域の例を(b)に示す。画像の分割数と同じ長さ  $x^2$  の領域にランダムに0と1を入れ、分割した領域を左上から横方向に順に見ていき、染色体で1が入っている領域を使用する領域として正規化相関係数の計算を行う。

次に個体の適応度を求める。以下に評価式を示す。

$$E = \min\left(\frac{\sum_{i=1}^{\alpha} R_c(i, j)}{\alpha}\right) - \max\left(\frac{\sum_{i=1}^{\alpha} R_w(i, k)}{\alpha}\right) \quad (2)$$

その位置を認識するのに有効な領域の情報を持つ個体ほど評価値を高く設定する必要がある。式中の第一項の  $R_c$  は同じ位置で撮影した別の画像との正規化相関係数を、第二項の  $R_w$  は全く別の位置で撮影した画像との正規化相関係数を表す。認識したい位置と同じ位置で撮影した画像との正規化相関係数は高い方がよく、全く別の位置で撮影した画像との正規化相関係数は低い方がよい。そのため差を取っている。同じ位置で撮影された画像および、全く別の位置で撮影された画像は複数枚あるため、 $R_c$ 、 $R_w$  は複数の値を持つ。そこでワーストケースを想定するために、同じ位置で撮影された画像との正規化相



関係数である  $R_c$  は最小値を、全く別の位置で撮影した画像との正規化相関係数  $R_w$  は最大値をとるものとする。式中のパラメータ  $i$  は領域番号を、 $j$ 、 $k$  は画像番号を、 $\alpha$  は領域数を表す。

### 3・2 環境情報重要度テーブルの生成

本研究ではマッチング時に画像を分割し、行動獲得時間に応じて正規化相関係数の計算に用いる領域の数を変化させることにより、状況に応じた自己位置推定を行う。このとき選択する領域は、その位置の特徴をより多く含んだ、自己位置推定に有効な領域から順に選択し正規化相関係数の計算に用いる事が重要である。そのためには各領域の重要度が必要となるため、各領域の重要度を示す環境情報重要度テーブルの生成を行う。3.2 節で説明した GA を用いた領域選択において、その位置の特徴をより多く含んだ自己位置推定に有効な領域は以下のような特徴を持つと考えられる。

- 自己位置推定に有効な領域を持った個体の評価値は高い
- GA による解探索の過程で選択される回数が多い

そこで、GA の各世代で評価値の上位  $x\%$  の各個体で選択されている領域に対し、(3)式に示すように、その個体の評価値  $E$  に対して重み付けを考慮したものを与える。

$$c = E \times w + 1 \quad (3)$$

重み付けを行わない場合は  $w = 0$  とするため常に  $c = 1$  となり、この場合単純に選択回数をカウントすることとなる。そして GA の解探索終了時に、各領域に与えられた値が高い順に領域に重要度を設定する。画像マッチング時には行動獲得時間の長さに応じて使用する領域の数を決定し、環境情報重要度テーブルを用いて重要度の高い領域から順に選択し、自己位置推定の計算に用いる。Fig.4 の(a)に生成した環境情報重要度テーブルの例を、(b)に環境情報重要度テーブルを用いた領域選択の方法



(a) Areas for self-position estimation

|     |     |     |     |     |     |     |    |
|-----|-----|-----|-----|-----|-----|-----|----|
| 483 | 245 | 24  | 15  | 11  | 32  | 24  | 62 |
| 71  | 122 | 22  | 221 | 282 | 62  | 86  | 81 |
| 67  | 62  | 320 | 62  | 33  | 14  | 34  | 85 |
| 62  | 62  | 44  | 62  | 64  | 86  | 75  | 6  |
| 75  | 201 | 500 | 75  | 32  | 17  | 177 | 37 |
| 57  | 73  | 7   | 80  | 58  | 300 | 34  | 73 |
| 85  | 9   | 46  | 48  | 96  | 41  | 52  | 4  |
| 25  | 86  | 64  | 95  | 14  | 48  | 86  | 6  |

(b) Example of information significance table

Fig.4 Self-position estimation with information significance table




Fig.5 Experimental environment

を示す。(b)の環境情報重要度テーブルにおいて最も大きな値の 500 が入っている領域を最も重要な領域として設定し、2 番目に大きな値である 483 が入っている領域を 2 番目に重要な領域として設定する。同様に 3 番目、4 番目、5 番目に重要な領域を設定する。

## 4.実験

### 4・1 実験環境

実験環境を Fig4 に示す。本学工学部 5 号館の 204(位置 A)、205(位置 B)、206(位置 C)号室の 3 箇所を認識位置として設定し、それぞれの位置で基準となる画像を取得した。この画像を元に、正規化相関係数の計算に用いる各位置の環境情報重要度テーブルを生成する。また実験用の入力画像として、各位置の基準となる点および、前後 10、20、30cm の点で画像計 7 枚を 20 セット取得した。この画像を基に各条件で生成した環境情報重要度テーブルを用いて領域数の変化に対する認識率の変化を比較する。各位置 140 枚の画像を入力画像とし、基準の画像となる各蓄積画像とのマッチングを行い、正しい位置で取得した蓄積画像との正規化相関係数が最も大きければ認識できているものとする。以下に実験で使用する各パラメータ等を示す。

#### <実験条件>

1. 画像サイズは  $320 \times 240$  [pixel] である
2. GA のパラメータで個体数は 500、世代数は 500 世代とする。この値は事前の実験により求めた、十分な解探索を行うために必要な数値である
3. 上位 250 個体を次世代に引継ぎ、一様交叉と突然変異によって残り 250 個体を生成する


4. 領域の最大数は、領域 1 個あたりの画素数 × 領域の最大数=3000 になるように、画像の分割数に応じて変化させる

#### 4・2 画像分割数に対する認識率の変化


各画像の分割数において環境情報重要度テーブルを生成し、生成した環境情報重要度テーブルを用いてテスト画像を用いた各位置における認識率実験を行った。各分割数における面積、および最大領域数を表 1 に示す。最大領域数は実験条件に示すように、使用する画素数の最大数により決定しており、また環境情報重要度テーブル

Tab.1 Maximum number of selected areas for allocation number


| Allocation Number | Area of selected areas[pixel] | Maximum of area |
|-------------------|-------------------------------|-----------------|
| 100               | 768                           | 4               |
| 256               | 300                           | 10              |
| 400               | 192                           | 16              |



(a) Allocation number: 100



(b) Allocation number: 256



(c) Allocation number: 400

Fig.6 Change of recognition success rate for allocation number change



(a) Position A



(b) Position B



(c) Position C

Fig.7 Selected areas by generated table

生成時のカウントは上位 0.2% とし、最も適応度が高い個体のみを調べている。

実験結果を Fig.6 に示す。一般的に分割数が多く、領域 1 個あたりサイズが小さいほど、画像中の特徴のある部分を無駄なく選択でき、高い認識率を得る事ができると考えられるが、逆に最も悪い結果となった。これは、領域 1 個あたりのサイズが小さいほど、ピンポイントで特徴のある部分を選択してしまうために、基準となる蓄積画像が撮影された位置に対して、ずれた画像を入力画像とした場合、ずれの影響により特徴のある部分が選択できていない事が原因である。逆に、領域 1 個あたりのサイズが大きい 100 分割の場合では、領域のサイズが大きすぎるために特徴部分以外の無駄な部分を多く含んでしまうために、特に位置 A の認識率があまりよくないと考えられる。この実験より、高い認識率を得るためには適切な分割数の設定が必要である事が分かる。

#### 4・3 GA のパラメータ変更時の認識率の変化

環境情報重要度テーブルの生成に適した手法、パラメータを決めるための以下のような実験を行った。

1. 環境情報重要度テーブルのために選択されている領域を調べる個体を上位 0.2%、2.0%、5.0% と変化
2. 重み付けのパラメータ  $w$  を 0.0、0.5、1.0 と変化

生成された環境情報重要度テーブルにおいて、選択されている領域の例を Fig.7 に示す。位置 A を認識するための環境情報重要度テーブルで選択されている領域で、画像中央付近のドアの境目ばかりが選択されている。これは外からの照明等の関係で影ができており、位置によって光の当たり方に違いがあるためにこのような位置が選




Fig. 8 Change of recognition success rate when parameters in GA selection were changed

択されている。また位置 B、位置 C においては張り紙の有無により特徴のある部分が選択されている場所があるものの、多くの領域が画像中央付近、及び左側に限定されており、画像右側は全く選択されていない事が分かる。パラメータを変化させたときの認識率の変化を Fig. 8 に示す。選択する領域数が少ないときは認識率に若干の差はあるが、領域数が最大の 10 個のときの認識率はほぼ同じになっている事が分かる。重要度の変化により、初期に選択される領域には違いがあるものの、最大の領域数 10 個のときに選択されている領域の組み合わせはほぼ同じだからである。これは GA を用いた組み合わせ探索において十分な個体数と世代数を設定しているため、多くの場合において 300 から 400 世代前後で準最適解に収束し、残り世代で、最終的に選ばれた領域のカウントが加算されるからである。また重み付け  $w = 1$  のときに  $w = 0$  および  $0.5$  の時に比べて識率が多少高い結果となった。これにより環境情報重要度テーブル生成に評価値である E が重要である事がわかる。


#### 4・4 実機による走行実験

上記の実験結果で最も高い認識率を得る事ができたパラメータ ( $x=2.0\%$ ,  $w=1$ ) で生成した環境情報重要度テーブルを用いて実機による走行実験を行い、環境情報重要度テーブルの有効性を検証する。本学工学部 5 号館 204 号室(位置 A)、205 号室(位置 B)、206 号室(位置 C)の 3 箇所を認識位置とし、それぞれ基準となる点から前後 30[cm]以内の範囲でランダムに走行中のロボットが自己位置推定を行い、正しい位置と認識できるかの実験を行う。実験結果を Fig. 9 に示す。環境情報重要度テーブルを用いない場合では、GA で選択された領域からランダムで選択を行い計算に用いた。環境情報重要度テーブルを用いない場合では全ての位置において領域数が増える事で認識率が増えており、環境情報重要度テーブルを用いた場合では領域数の変化にかかわらず安定した認識率を得られている事が確認できる。これにより環境情報重要


度テーブルを用いる事で、自己位置推定により重要な情報を持った領域から順に選択し、計算に用いる事ができている事がわかる。また計算時間においては全ての位置で領域数に対してほぼ比例する結果となった。

#### 5. まとめ


本研究では自己位置推定に用いる時間を減らしたときに生じる認識精度の低下を問題点し、そして問題点を解決する方法として情報の重要度に着目した。そして自己位置推定に用いる情報に重要度を設定した環境情報重要度テーブルを生成し、自己位置推定に重要な情報から順に正規化相関係数の計算に用いる事で、自己位置推定に用いる時間を減らしてもできるだけ状況認識の精度を低下させない方法を提案した。提案手法の有効性を示すために実験を行い結果について述べた。また、実験結果から提案手法を用いた自己位置推定方法の有効性を示した。



(a) Position A



(b) Position B



(c) Position C

Fig. 9 Experimental results with real-robot

参考文献

- [1] 藤沼、石川、小石川 “ 簡易産業用ロボットに関する研究（第3報） ” 、茨城県工業技術センター研究報告 No.14, 1986
- [2] 藤澤、早川、青木、鈴木、大熊 “ 自律移動ロボットにおける実時間行動探索 ” , 日本ロボット学会誌 Vol.17, No.4, pp.503-512, 1999.
- [3] 斎藤 “ 遺伝的アルゴリズムを用いた画素選択テンプレートによる画像マッチング ”、電子情報通信学会論文誌、Vol.J81-D-II, No.3 pp.488-499, 2001.
- [4] 伊庭 “ 遺伝的プログラミング ”、東京電機大学出版局, 1996.

( 受理 平成 19 年 3 月 19 日 )